稀疏正则化逆向神经网络在双陷波超宽带天线设计中的应用 *

南敬昌，王梓琦，高明明

(辽宁工程技术大学 电子与信息工程学院, 辽宁 葫芦岛市 125105)

摘　要：针对直接逆向神经网络模型精度较低，BP 逆向神经网络泛化能力较差以及单独使用 HFSS 仿真软件需要不断优化天线各参数增加了设计时间的问题，提出一种将 HFSS 与稀疏正则化逆向神经网络联合的方法对双陷波超宽带天线进行设计。该方法在逆向神经网络性能函数中增加 L1/2 范数和 L2 范数，L1/2 范数引入了新的权系数，扩充了输入样本向量，使网络更易得到稀疏性解，逆模型精度更高，L2 范数能有效避免过拟合现象，使网络泛化能力更强。应用于双陷波超宽带天线设计中，采用在辐射贴片上开弧形槽的方式产生陷波特性，根据天线目标电压驻波比逆向求解对应的开槽尺寸。仿真实验结果表明，与 BP 逆向神经网络方法相比，求得的与天线电压驻波比对应的开槽角度相对误差减小了 69.3%，开槽半径相对误差减小了 88.7%，网络运行时间减少了 15.9%；最终设计的天线带宽为 2.4~11 GHz，实现了 3.31~3.8 GHz 和 4.98~6.05 GHz 的良好陷波特性，缩短了整个天线的设计周期。

关键词：逆向神经网络；HFSS；L1/2 范数；L2 范数；双陷波超宽带天线

中图分类号：TP183　　doi: 10.3969/j.issn.1001-3695.2018.02.0109

Application of sparse regularized inverse neural network in design of dual-notch UWB antenna

Nan Jingchang, Wang Ziqi, Gao Mingming

(*College of Electrics & Information Engineering Liaoning Technical University*, *Huludao Liaoning Province* 125105, *China*)

Abstract: Aiming at the low accuracy of direct inverse neural network model, the poor generalization ability of BP neural network, and the increased design time due to the fact that antenna parameters need to be optimized continuously using HFSS simulation software individually, this paper proposed a new method , which combined HFSS with sparse regularization inverse neural network to design the dual band-notched ultra-wide band antenna. This method added L1/2 norm and L2 norm in the performance function of the inverse neural network. The L1/2 norm introduced a new weight coefficient, expanded the input sample vector, made the network to obtain the sparsity solution more easily, and the inverse model got higher accuracy. Meanwhile, the L2 norm avoided the over-fitting phenomenon effectively and made the network generalization ability stronger. It applied to the design of dual band-notched ultra-wide band antenna, using of arc grooves on radiating patches generated notch characteristics, and according to the antenna target voltage standing wave ratio(VSWR) solved inversely the corresponding slot size. Simulation results show that the relative error of slot angle which corresponding to VSWR of the antenna reduced by 69.3%, and the relative error of slot radius lessened by 88.7%, and the network running time decreased by 15.9% compared with BP neural network method. The final designed antenna bandwidth is 2.4~11 GHz, achieves the good notch characteristics in 3.31~3.8 GHz and 4.98~6.05 GHz, and shortens the entire antenna design cycle.

Key words: Inverse neural network; HFSS; L1/2 norm; L2 norm; dual band-notched UWB antenna;

0　引言

近年来，随着无线通信技术的快速发展，天线发挥着不可或缺的作用，它是承载发射和接收无线电磁波、完成电磁转换的核心部件[1]。其中，超宽带通信系统占用的频段范围很广，其间覆盖了许多窄带通信标准，如 IEEE 802.16 全球微波接入(worldwide interoperability for microwave access， WIMAX，3.3~3.7 GHz)，IEEE 802.11a 无线局域网(wireless local area network，WLAN，5.15-5.35GHz/5.725~5.825 GHz)等。而超宽带系统的发射功率相对较低，很容易与这些窄带通信系统之间形成串扰，因此具有陷波特性的超宽带天线被提出，其陷波特性可以通过改变谐振结构的尺寸和位置，或通过改变辐射贴片上

收稿日期：2018-02-14；**修回日期**：2018-04-11　　**基金项目**：国家自然科学基金面上项目（61372058）；辽宁省高校重点实验室项目（LJZS007）；辽宁省教育厅科学研究一般项目（L2015209）

作者简介：南敬昌（1971-），男，河南滑县人，教授，硕导，博士，主要研究方向为射频电路与系统、电路系统与电磁仿真、信号处理与信息编码等；王梓琦+（1992-），女（通信作者），辽宁盘锦人，硕士研究生，主要研究方向为射频微波器件神经网络逆向建模（1172828469@qq.com）；高明明（1980-），女（满族），内蒙古人，副教授，博士，主要研究方向为无线通信、射频微波电路建模仿真技术.

缝隙的长度、宽度等尺寸来改变[2,3]。传统的陷波天线设计与分析方法采用基于计算机的辅助设计方法（computer aided design, CAD），如高频结构仿真器 HFSS 等。在设计过程中，若天线的目标参量发生改变，则需要重新优化仿真，增加了设计时间，加大了设计难度。

神经网络以其并行计算能力，对于大型复杂非线性问题能快速建模求解等优点在射频微波天线建模与设计中得到了广泛应用。正向神经网络建模方法通过选择一个适当的神经网络模型来逼近或替代实际的器件[4]；逆向神经网络建模方法被训练用来设计器件，它可以通过给定的目标电参量综合出对应的模型参量[5,6]。对于直接逆向神经网络，可以通过交换网络的输入输出数据来获得，其优点是建模速度快，但是由于输入与输出参量之间的多值映射关系，难以保证其收敛性和唯一性[7]； Vai 等人错误!未找到引用源。提出了双向 BP 神经网络建模方法，将正向建模与逆向设计方法联合，根据异质结双极晶体管放大器的频率响应对其电容电感进行逆向求解，这种方法使得解搜索过程变快，但对设计参数偏差不敏感； Mareddy 等人错误!未找到引用源。提出了对于多输入模型建立一系列候选逆模型的梯度逆向神经网络建模方法,将具有最小误差的候选逆模型作为理想逆模型与原始模型互补得到精确模型，并应用于传输线和螺旋电感的建模中，但这种方法的模型输出仅有一个，降低了建模效率；Kabir 等人[7]提出在逆向神经网络训练前对数据进行分组处理的设计方法，根据分组规则消除多解问题，将各子逆模型的输出作为正向模型的输入，再选出满足要求的子逆模型按照一定规则合并，应用于波导滤波器三个关键参数设计中，这种方法过程复杂，精度易受子模型精度影响；Gosal 等人[10]基于此分组逆向神经网络分别利用 PSO（particle swarm optimization）算法和 GA（genetic algorithm）算法[11]优化的神经网络逆向建模技术，根据天线相位角逆向求解导体元件尺寸，用于传输阵列天线的设计中，但这种优化方法需要建立多个子模型较为复杂且耗时。

针对上述直接逆向建模方法模型精度不高，其他逆向神经网络方法过程复杂，整个逆模型精度易受子模型精度影响以及单独使用 HFSS 软件设计天线，需要不断优化仿真十分耗时的问题，提出一种将稀疏正则化逆向神经网络与 HFSS 仿真软件联合设计的方法，通过改进的神经网络逆向求解方法取代了连续搜索的程序优化方法，在逆向神经网络性能函数中引入 $L_{1/2}$ 范数和 L_2 范数，$L_{1/2}$ 范数扩充了输入样本向量，使得逆模型更易得到稀疏性解，且精度更高，而 L_2 范数能够有效避免过拟合现象，使得网络泛化能力更强，模型输出更加平滑。结合 HFSS 仿真软件，对双陷波超宽带天线进行设计，根据天线目标电压驻波比确定开槽尺寸，最终实现了良好的双陷波特性，成功滤除了 WIMAX 和 WLAN 频段的干扰。此方法不需要建立单独的逆模型，在正模型的基础上实现了逆设计功能，在保证设计精度的同时，提高了设计速度，为天线的智能化设计提供了有效的解决方案。

1　稀疏正则化逆向神经网络算法

1.1　逆向神经网络

本文采用具有一个输入层，两个隐含层和一个输出层的逆向神经网络结构，如图 1 所示。

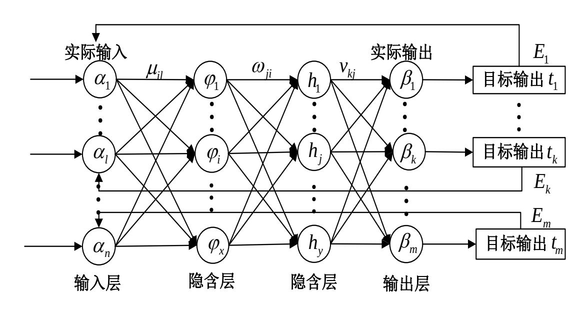


图 1 逆向神经网络结构图

其中 $\alpha=(\alpha_1,\cdots,\alpha_l,\cdots,\alpha_n)$ 是输入向量，$\beta=(\beta_1,\cdots,\beta_k,\cdots,\beta_m)$ 是输出向量，μ_{il} 是输入层第 l 个神经元和隐含层第 i 个神经元之间的权值，ω_{ji} 是隐含层第 i 个神经元到隐含层第 j 个神经元的权值，v_{kj} 是隐含层第 j 个神经元到输出层第 k 个神经元之间的权值；φ_{iq} 为第一个隐含层第 i 个神经元输出，h_{jq} 为第二个隐含层第 j 个神经元输出，E 是目标输出向量 t 与实际输出向量 β 之间的误差函数。传递函数采用 tansig 函数 $T(\bullet)$，$T(\bullet)$ 的导数为 $T'=1-T^2$。此神经网络输出 β_k 可以被计算为

$$\beta_k(rl)=2/\left(1+exp\left(-2*(rl)\right)\right)-1 \qquad (1)$$

其中，rl 是加权输入。

不同于正向建模中网络权值的改变，逆向神经网络的误差是由输入参量引起的，因此需要不断修正输入参量的值。更新公式如式（2）所示。

$$\alpha_{lq}^{(n+1)}=\alpha_{lq}^{(n)}-\eta\frac{\partial E}{\partial \alpha_{lq}^{(n)}} \qquad (2)$$

其中：q 表示第 q 组测试数据，$\alpha_{lq}^{(n+1)}$ 为更新后的第 $n+1$ 个参数，$\alpha_{lq}^{(n)}$ 为更新前的第 n 个参数，η 为学习速率。

1.2　逆向神经网络建模过程

对于正向神经网络建模方法，可以通过已知器件的输入几何参数和输出电参数建立相应的器件模型。本文的逆向神经网络建模过程则是在正向模型的基础上通过逆向迭代算法实现逆设计功能，效率更高。

具体方法如下：

a)根据器件已知的输入几何参数和输出电参数建立器件正向模型；

b）提取正向模型的权值参数；

c）保持权值参数不变，根据逆模型目标输出电参数，利用稀疏正则化逆向神经网络学习算法更新逆模型输入几何参数，使误差函数 E 最小或满足最大迭代次数；

d)通过实际输出几何参数和目标几何参数之间的偏差来描述模型性能好坏。

1.3　稀疏正则化逆向神经网络学习算法及其理论性能

直接逆向神经网络建模方法通过直接交换输入输出数据来获得逆模型，其精度难以保证，基于 BP 神经网络的逆向迭代算法存在泛化能力较差的缺点，而分组逆向神经网络建模方法过程复杂、整个模型精度易受子模型精度影响，因此，提出一种稀疏正则化逆向神经网络学习算法。

正则化方法可以通过在最小化误差性能函数中加入约束项的方式[12]，实现对模型参数的约束，达到简化模型，获得稀疏平滑解的目的。其中，L_2 范数是常用的正则化方法，在其误差性能函数中引入 L_2 范数可以得到：

$$E = E_0 + \lambda_2 * \sum_{q=1}^{q} \|\omega\|_2 = E_0 + \lambda_2 * \sum_{q=1}^{q} |\omega|^2 \qquad (3)$$

其中：E_0 代表初始误差性能函数，第二项为 L_2 惩罚项，λ_2 是惩罚项系数，对误差函数求导可得：

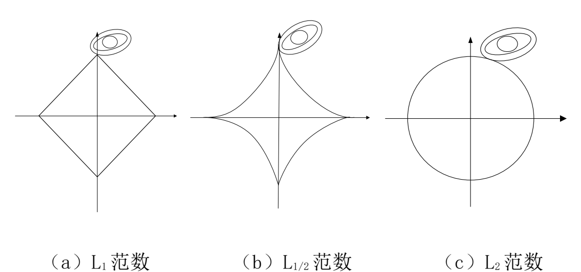
$$\frac{\partial E}{\partial \omega} = \frac{\partial E_0}{\partial \omega} + 2\lambda_2 \omega \qquad (4)$$

因此，权值更新为

$$\begin{aligned} \omega &= \omega - \eta \frac{\partial E_0}{\partial \omega} - 2\lambda_2 \omega \\ &= (1-2\lambda_2)\omega - \eta \frac{\partial E_0}{\partial \omega} \end{aligned} \qquad (5)$$

未引入 L_2 惩罚项时，权值参量 ω 前系数为 1，引入 L_2 惩罚项后，系数变为 $1-2\lambda_2$，其中 $0<\lambda_2<1$，则有 $1-2\lambda_2<1$，具有权重衰减效果，由此可知引入 L_2 范数的意义在于限制了模型参量的值，使得模型输出更加平滑，避免了过拟合现象，对测试数据的拟合效果更好。

而作为具有稀疏化效果的 L_0 范数是指向量中非 0 元素的个数，利用 L_0 范数来约束权值参数，简化了模型结构，但 L_0 范数存在难以优化求解的问题。L_1 范数是 L_0 范数的最优凸近似，从模型空间的角度出发，L_1 范数的约束区域如图 2(a)所示为一个正方形，约束区域与误差函数等高线首次相交的地方就是最优解，当相交点汇聚在坐标轴时有 ω=0，产生一个零系数解，具有稀疏性。徐宗本等人提出在稀疏意义下，$L_{1/2}$ 范数能对网络进行有效的剪枝[13][14]，与 L_1 范数相比，$L_{1/2}$ 范数的约束区域与等高线存在明显的交点，如图 2(b)所示，更易得到具有稀疏性的解。但对于 L_2 范数，如前所述，在训练过程中能大大改善过拟合现象，提高网络泛化能力，然而由图 2(c)可以看出没有存在与坐标轴明显的交点，即在首次相交处出现具有稀疏性解的概率非常小，稀疏化能力稍显不足。



（a）L_1 范数　　（b）$L_{1/2}$ 范数　　（c）L_2 范数

图 2 三种范数的稀疏性解

基于上述两种范数的性能，在 BP 逆向神经网络误差性能函数中同时引入 $L_{1/2}$ 范数和 L_2 范数作为惩罚约束项，令 L_2 范数最小，即模型各元素更接近于零，使得输出更加平滑，避免了过拟合现象，但它使得算法的计算复杂度增加，因此引入 $L_{1/2}$ 范数，新增的 $L_{1/2}$ 范数使得模型部分参数等于零，减少了非零参数的数量，具有稀疏意义，使得模型在较少的参数作用下更易得到稀疏性解。然而，$L_{1/2}$ 范数在追求稀疏性的同时，是以牺牲对于局部特征的描述为代价的，而 L2 范数的作用是当 λ_2 充分大时，可以收缩待估计参数，产生平滑的输出向量，提高了网络的泛化能力，补偿了这一不足。由于逆向神经网络迭代算法的误差 E 是由输入参量 α_{lq} 引起的，因此其误差性能函数 E 为

$$E = \sum_{q=1}^{q} E_q = \frac{1}{2} \sum_{q=1}^{q} \sum_{k=1}^{m} \left(\beta_{kq} - t_{kq}\right)^2 + \lambda_{1/2} * \sum_{q=1}^{q} \|\alpha_{lq}\|_{1/2} + \lambda_2 * \sum_{q=1}^{q} \|\alpha_{lq}\|_2 \qquad (6)$$

其中：$\|\cdot\|_{1/2}^{1/2}$ 表示 $L_{1/2}$ 范数，$\|\alpha_{lq}\|_{1/2} = \sum_{q=1}^{q} |\alpha_{lq}|^{1/2}$，$\|\cdot\|_2$ 表示 L_2 范数，$\|\alpha_{lq}\|_2 = \sum_{q=1}^{q} |\alpha_{lq}|^2$，$\lambda_{1/2}$，$\lambda_2 > 0$ 是惩罚项系数。

为了求得稀疏正则化逆向神经网络的迭代算法公式，需要求解式（6）性能函数关于输入参量 α_{lq} 的导数，将其分解为以下三个独立的优化问题：

$$E_x = \frac{1}{2} \sum_{q=1}^{q} \sum_{k=1}^{m} \left(\beta_{kq} - t_{kq}\right)^2 \qquad (7)$$

$$E_y = \lambda_{1/2} * \sum_{q=1}^{q} \|\alpha_{lq}\|_{1/2} \qquad (8)$$

$$E_z = \lambda_2 * \sum_{q=1}^{q} \|\alpha_{lq}\|_2 \qquad (9)$$

第一个隐含层输出 φ_{iq} 可由下式计算：

$$\varphi_{iq} = T\left(\sum_{l=1}^{n} \mu_{il} * \alpha_{lq}\right) \qquad (10)$$

输出值 φ_{iq} 对第 l 个输入值 α_{lq} 的偏导为：

$$\frac{\partial \varphi_{iq}}{\partial \alpha_{lq}} = \mu_{il} * (1 - \varphi_{iq}^{\ 2}) \qquad (11)$$

第二个隐含层输出 h_{jq} 可由下式计算：

$$h_{jq} = T\left(\sum_{i=1}^{x} \omega_{ji} * \varphi_{iq}\right) \qquad (12)$$

输出值 h_{jq} 对输入值 φ_{iq} 的偏导为

$$\frac{\partial h_{jq}}{\partial \varphi_{iq}} = \omega_{ji} * (1 - h_{jq}^{\ 2}) \qquad (13)$$

隐含层输出 h_{jq} 对输入值 α_{lq} 的偏导为

$$\frac{\partial h_{jq}}{\partial \alpha_{lq}}=\frac{\partial h_{jq}}{\partial \varphi_{iq}}*\frac{\partial \varphi_{iq}}{\partial \alpha_{lq}}=\omega_{ji}*(1-h_{jq}^{2})*\mu_{il}*(1-\varphi_{iq}^{2}) \quad (14)$$

此网络第 k 个输出值 β_{kq} 可以被计算为：

$$\beta_{kq}=T\left(\sum_{j=1}^{y}v_{kj}*h_{jq}\right) \quad (15)$$

第 k 个输出值 β_{kq} 对输出值 h_{jq} 的偏导为

$$\frac{\partial \beta_{kq}}{\partial h_{jq}}=v_{kj}*(1-\beta_{kq}^{2}) \quad (16)$$

那么，式（6）中性能函数 E 对于输入向量 α_{lq} 的偏导为

$$\frac{\partial E}{\partial \alpha_{lq}}=\sum_{q=1}^{q}\left[\frac{\partial E_{xq}}{\partial \alpha_{lq}}+\frac{\partial E_{yq}}{\partial \alpha_{lq}}+\frac{\partial E_{zq}}{\partial \alpha_{lq}}\right] \quad (17)$$

误差函数 E_{xq} 对于输入参量 α_{lq} 的偏导为

$$\frac{\partial E_{xq}}{\partial \alpha_{lq}}=\frac{\partial E_{xq}}{\partial h_{jq}}\cdot\frac{\partial h_{jq}}{\partial \alpha_{lq}}=\left(\frac{\partial E_{xq}}{\partial \beta_{kq}}\cdot\frac{\partial \beta_{kq}}{\partial h_{jq}}\cdot\frac{\partial h_{jq}}{\partial \alpha_{lq}}\right) \quad (18)$$

设式（18）中的第一个因子如式（19）所示。

$$\frac{\partial E_{xq}}{\partial \beta_{kq}}=\frac{\partial\left[\frac{1}{2}\sum_{k=1}^{m}\left(\beta_{kq}-t_{kq}\right)^{2}\right]}{\partial \beta_{kq}}=\sum_{k=1}^{m}\left(\beta_{kq}-t_{kq}\right) \quad (19)$$

将式（19）（16）（14）代入式（18）可得：

$$\frac{\partial E_{xq}}{\partial \alpha_{lq}}=\sum_{k=1}^{m}\left(\beta_{kq}-t_{kq}\right)*v_{kj}*\left(1-\beta_{kq}^{2}\right)*\omega_{ji}*\left(1-h_{jq}^{2}\right)*\mu_{il}*\left(1-\varphi_{iq}^{2}\right) \quad (20)$$

误差函数 E_{yq} 关于输入参量 α_{lq} 的偏导为

$$\frac{\partial E_{yq}}{\partial \alpha_{lq}}=\lambda_{1/2}*\frac{sgn\left(\alpha_{lq}\right)}{2\left|\alpha_{lq}\right|^{1/2}} \quad (21)$$

其中：$sgn(\cdot)$ 为符号函数。误差函数 E_{zq} 关于输入参量 α_{lq} 的偏导为

$$\frac{\partial E_{zq}}{\partial \alpha_{lq}}=2\lambda_{2}*\alpha_{lq} \quad (22)$$

因此，将式（20）~（22）代入到式（17）中可得

$$\frac{\partial E}{\partial \alpha_{lq}}=\sum_{q=1}^{q}\left[\frac{\partial E_{xq}}{\partial \alpha_{lq}}+\frac{\partial E_{yq}}{\partial \alpha_{lq}}+\frac{\partial E_{zq}}{\partial \alpha_{lq}}\right]=\sum_{q=1}^{q}\left[\sum_{k=1}^{m}\sum_{j=1}^{y}\sum_{i=1}^{x}\begin{matrix}\left(\beta_{kq}-t_{kq}\right)*v_{kj}*\left(1-\beta_{kq}^{2}\right)*\\ \omega_{ji}*\left(1-h_{jq}^{2}\right)*\mu_{il}*\left(1-\varphi_{iq}^{2}\right)\end{matrix}+\lambda_{1/2}*\frac{sgn\left(\alpha_{lq}\right)}{2\left|\alpha_{lq}\right|^{1/2}}+2\lambda_{2}*\alpha_{lq}\right] \quad (23)$$

将式（23）代入式（2）中，对输入几何参量迭代更新，实现逆向求解过程。在网络训练过程中调整正则化系数 $\lambda_{1/2}$ 和 λ_2 的大小，调节了 $L_{1/2}$ 范数和 L_2 范数的比重来平衡稀疏和平滑两个问题，使其目标误差函数达到最小，网络性能最优。

2　天线结构

采用本文提出的稀疏正则化逆向神经网络对双陷波超宽带天线的陷波特性进行设计。其双陷波超宽带天线结构如图 3 所示。该天线采用厚度为 1.6 mm，长度为 44 mm，宽度为 38 mm 的介质基板；该天线的辐射贴片由两个半圆形贴片组成，大半圆半径 R 为 11 mm；小半圆半径 r 为 7.5 mm；馈线宽度 W_f 为 3.2 mm；接地板高度 L_f 为 18 mm；馈线距离接地板缝隙宽度 s 为 0.15 mm；大半圆辐射贴片与接地板之间的高度 g 为 0.2mm；两个弧形槽的开槽角度 A_1，A_2；开槽的半径 R_1，R_2；以及槽的宽度 s_1，s_2。

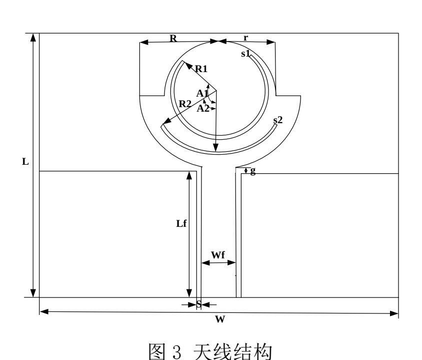


图 3　天线结构

3　逆向神经网络确定天线关键设计参数

将神经网络逆向建模技术应用到天线的设计中可以加快设计速度。在确定天线设计参数与响应值之间的关系后，只需将目标响应输入给神经网络逆模型，它就可以快速地求解天线各个设计参数。

采用本文提出的逆向神经网络对此超宽带天线进行设计，为解决窄带频段 WIMAX 和 WLAN 的干扰问题，此天线通过在辐射贴片上开两个弧形槽的方法产生双陷波特性，因此，该天线的关键设计参数是两个弧形槽的开槽角度 A_1，A_2，半径 R_1，R_2，在 HFSS 软件仿真的基础上，使用神经网络逆设计方法求解双陷波超宽带天线的关键尺寸。

具体逆建模流程如下：

确定参数。网络输入参数——A_1，R_1 和 f_1（或 A_2，R_2 和 f_2），输出参数——电压驻波比 $VSWR_1$（或 $VSWR_2$）；使用 HFSS 软件提取天线训练数据。在低频 f_1 范围为 3GHz~4GHz 处，当 A_1 从 110deg~120deg，R_1 从 5mm~7mm，对应的 $VSWR_1$ 范围为 2.4~5.4。

训练神经网络正向模型。将 2）中提取的数据分为训练集和测试集，获得神经网络正向模型，提取权值并保存；

神经网络逆向求解。保持正向神经网络的权值不变，通过使模型的输出（电压驻波比 $VSWR$）与目标电压驻波比 $VSWR'$ 相等或保持在一定的误差范围内，逆向迭代求解网络的输入（几何参数），以此来实现逆向求解超宽带天线几何参数的目的。该神经网络逆模型一旦训练好就意味着低频处参数 A_1，R_1 和 $VSWR_1$ 之间的关系已经确定；

利用神经网络逆模型求出当 f_1 为 3.4GHz，$VSWR_1$ 最大值时的 A_1 和 R_1 值。此时的 A_1 和 R_1 值就是当天线在 3.4GHz 处产生最佳陷波特性时的 A_1 和 R_1 值。

同理，在高频 f_2 范围为 5GHz~7GHz 处，当 A_2 从

50deg~60deg，R_2 从 8mm~10mm，对应的 $VSWR_2$ 范围为 3.1~8.8。得到了高频处输入 A_2， R_2 参数与输出 $VSWR_2$ 之间的关系后，将这些数据输入到神经网络逆模型中；

建立神经网络逆模型。网络输入为 A_2，R_2，输出为 $VSWR_2$；逆向求解出当 f_2 为 5.6GHz， $VSWR_2$ 最大值时对应的 A_2 和 R_2 值。此时的 A_2 和 R_2 值就是当天线在 5.6GHz 处产生最佳陷波特性时的 A_2 和 R_2 值。

最后，将得到的 A_1， A_2， R_1， R_2 参数值代入到 HFSS 软件中仿真，若仍存在误差则在 HFSS 中进行微调。

4 稀疏正则化逆向神经网络天线仿真结果及分析

采用传统的基于高频结构仿真器 HFSS 的搜索优化方法，一旦天线的任意一个参数值改变，都需要重新仿真，增加了设计代价。而基于逆向神经网络的器件模型一旦建好，其求解速度快于 HFSS 软件方法，不需要已知器件的先验知识，提高了设计效率。这里，将本文提出的稀疏正则化逆向神经网络建模方法与 BP 逆向神经网络建模方法、直接逆向建模方法和 HFSS 软件仿真方法进行比较。

4.1 超宽带天线双陷波特性分析

此双陷波超宽带天线开槽角度 A_1 和半径 R_1 值对天线 $VSWR_1$ 的影响曲线如图 4 和 5 所示。在低频处随着 A_1 和 R_1 值的增大，陷波中心频率向左移动， $VSWR_1$ 也不断增大。而在高频附近，$VSWR_1$ 曲线陷波中心频率几乎没有偏移。因此从图 4、5 中可以知道，第一处陷波是 A_1、R_1 对应的弧形槽产生的，$VSWR_1$ 值及陷波中心频率会随着 A_1 和 R_1 值的变化而变化。

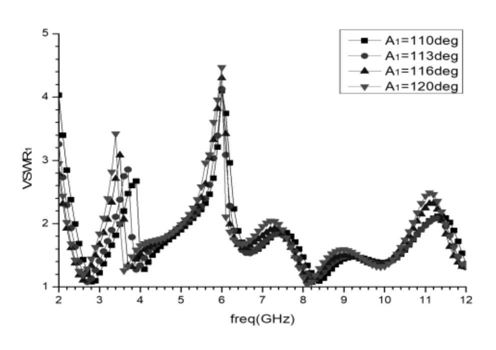


图 4 A_1 不同值对 $VSWR_1$ 的影响曲线

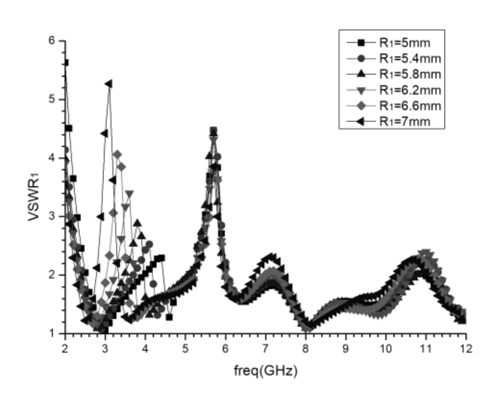


图 5 R_1 不同值对 $VSWR_1$ 的影响曲线

角度 A_2 和半径 R_2 的值对 $VSWR_2$ 的影响曲线如图 6 和 7 所示。在高频处，随着 A_2 和 R_2 值的增大陷波中心频率依次左移，$VSWR_2$ 值也不断增大。而在低频附近，陷波中心频率几乎没有变化。这说明第二处陷波是 A_2、R_2 对应的弧形槽产生的，$VSWR_2$ 值和陷波中心率会随着 A_2 和 R_2 值的变化而变化。

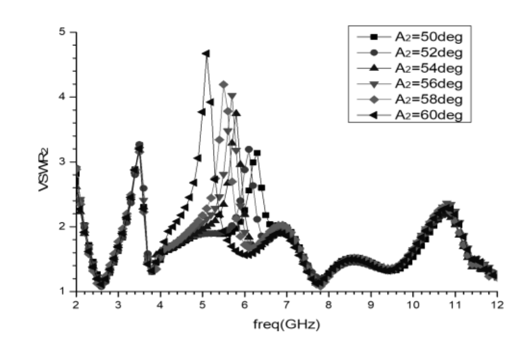


图 6 R_1 不同值对 $VSWR_2$ 的影响曲线

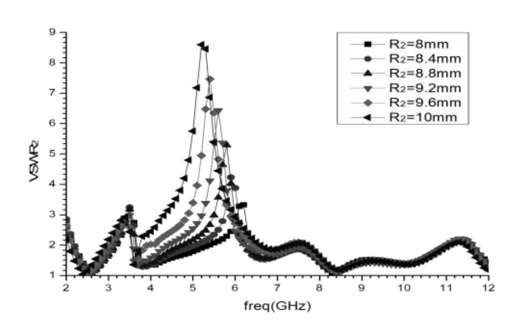


图 7 R_2 不同值对的 $VSWR_2$ 影响曲线

天线的 s_1 参数对天线陷波中心频率的影响曲线如图 8 所示。s_1 参数变化时，天线的陷波中心频率基本不变，它主要影响此天线的陷波带宽。这里，当 s_1 取一个固定值时，此天线高频和低频处的陷波中心频率主要受开槽角度和半径的影响。同理，可知 s_2 参数对天线陷波中心频率的影响。

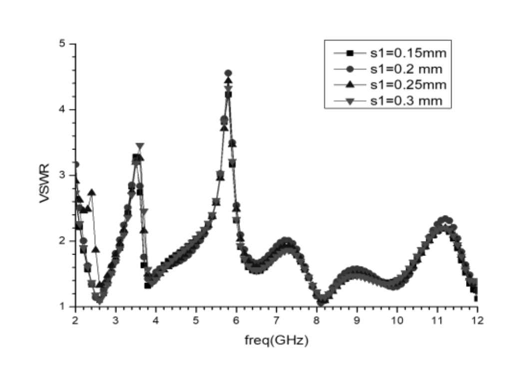


图 8 s_1 对天线陷波中心频率的影响

4.2 逆向神经网络天线仿真结果分析

这里，以低频 f_1 范围为 3GHz~4GHz 处角度 A_1、半径 R_1 与 $VSWR_1$ 的关系为例，比较本文逆向神经网络建模方法、BP 逆向神经网络建模方法、直接逆向建模方法和 HFSS 软件仿真方法的仿真结果。

利用 HFSS 软件中的天线模型提取 1000 组数据，在低频处，角度 A_1 取值范围为 110deg~120deg，间隔为 1deg，半径 R_1 取值范围为 5mm~7mm，间隔为 0.2mm，相应的 $VSWR_1$ 范围为 2.4~5.4。为使量纲保持一致，首先，对数据进行归一化处理。

分别取 920 组训练数据和 50 组测试数据，根据实验情况，本文逆向建模方法隐含层神经元个数第一层取 10，第二层取 12，学习速率取为 0.17，误差限设为 1e-5，最大迭代次数设为 1000，惩罚项系数 $\lambda_{1/2}$ 取 0.15，λ_2 取 0.2。惩罚项系数变化时，逆模型 50 组 A_1、R_1 测试输出与实际输出误差比较如表 1 所示。

表 1　惩罚项系数变化时误差比较

$\lambda_{1/2}$	λ_2	A_1 误差	R_1 误差	$\lambda_{1/2}$	λ_2	A_1 误差	R_1 误差
	0.05	0.373	0.0398		0.05	0.201	0.0267
	0.10	0.381	0.0357		0.1	0.198	0.0376
0.05	0.15	0.232	0.0372	0.15	0.15	0.173	0.0201
	0.2	0.252	0.0401		0.2	0.101	0.0104
	0.25	0.271	0.0474		0.25	0.135	0.0203
	0.05	0.223	0.0365		0.05	0.259	0.0139
	0.10	0.274	0.0387		0.1	0.176	0.0346
0.1	0.15	0.259	0.0253	0.2	0.15	0.225	0.0228
	0.20	0.296	0.0281		0.2	0.269	0.0241
	0.25	0.283	0.0211		0.25	0.247	0.0308

将三种逆建模方法求得的角度 A_1、半径 R_1 与 HFSS 软件仿真结果进行对比，对比结果及测试误差如图 9、10、11、12 所示。

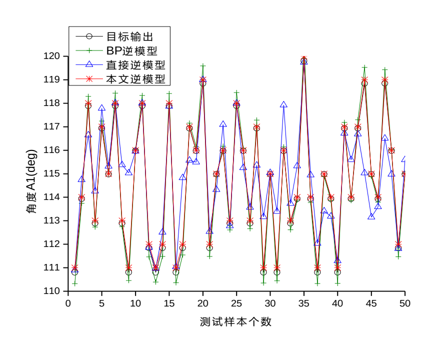


图 9　角度 A_1 拟合曲线

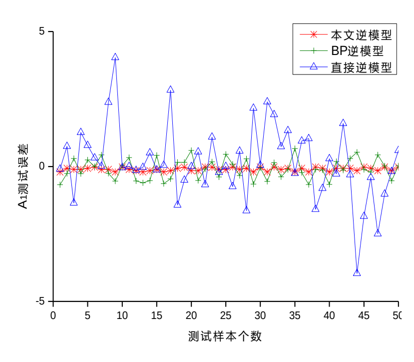


图 10　角度 A_1 测试误差对比图

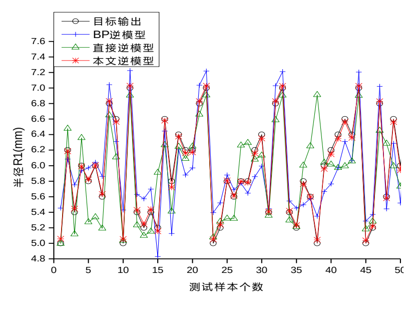


图 11　半径 R_1 拟合图

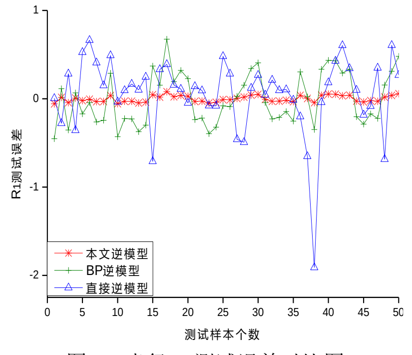


图 12　半径 R_1 测试误差对比图

对于直接逆向建模方法，其输入输出关系存在一对多的多解问题，导致模型精度不高。BP 逆向建模方法与本文逆建模方法相比，测试误差偏大，其主要原因是训练过度造成的过拟合现象。由于本文采用将 L_2 范数与 $L_{1/2}$ 范数相结合的逆向迭代算法，逆模型精度更高，网络泛化能力更强。对比结果如表 2 所示，与 BP 逆建模方法相比，网络运行时间减少了 15.9%，A_1 相对误差减小了 69.3%，R_1 相对误差减小了 88.7%。

表 2　三种逆建模方法结果对比

	运行时间/s	A_1 平均误差/deg	R_1 平均误差/mm
直接逆建模方法	13.37	1.065	0.3422
BP 逆建模方法	10.39	0.329	0.0928
本文方法	8.742	0.101	0.0104

5　天线设计结果及分析

最终，采用本文逆向建模方法所设计的双陷波超宽带天线的各个参量的数值如表 3 所示。

表 3　天线各尺寸参数

参量	数值	参量	数值
W	38.0mm	g	0.2mm
L	44.0mm	s_1	0.2mm
R	11.0mm	s_2	0.2mm
r	7.5mm	A_1	117.2deg
W_f	3.2mm	A_2	55deg
L_f	18mm	R_1	6.4mm
s	0.15mm	R_2	8.7mm

天线阻抗的实部和虚部如图 13 所示，实线为天线阻抗的实部近似为 50Ohm，虚线为天线阻抗的虚部近似为 0Ohm，阻抗匹配效果较好。

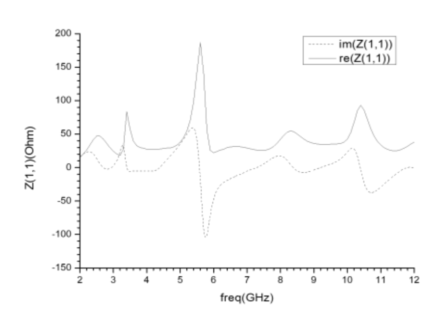


图 13　天线阻抗曲线图

天线在低频 3.4GHz 处的 H 面和 E 面辐射方向图如图 14 所示，在高频 5.6GHz 处的 H 面 E 面辐射方向图如图 15 所示，天线的全向性良好。

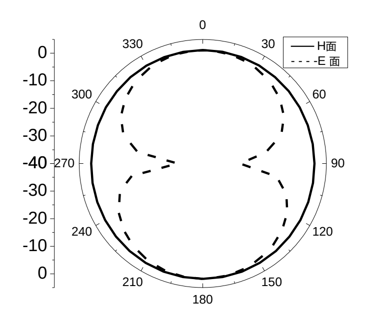


图 14 3.4GHz 处天线 H 面和 E 面方向图

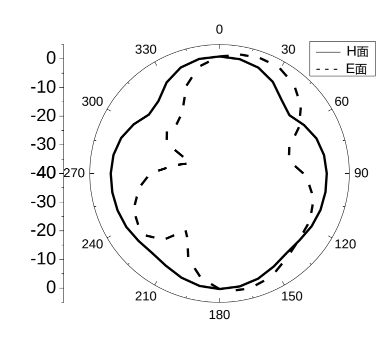


图 15 5.6GHz 处天线 H 面和 E 面方向图

天线电压驻波比 *VSWR* 仿真曲线如图 16 所示。此天线除陷波频段外，在 2.4GHz~11GHz 的范围内 *VSWR* 均小于 2，并在 3.4GHz 和 5.6GHz 处产生了良好的陷波特性。

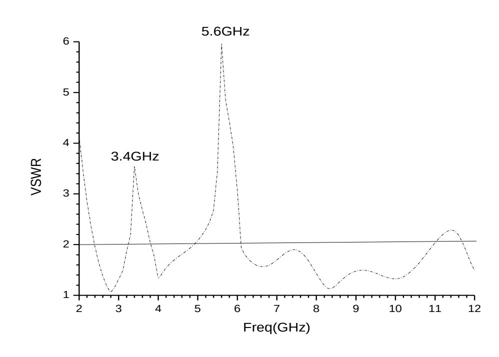


图 16 天线 *VSWR* 曲线

天线的实物图如图 17 所示。天线实际尺寸为 38mm×44mm×1.6mm。

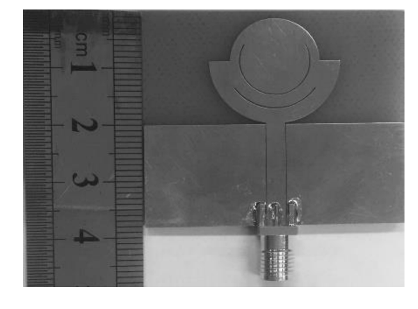


图 17　双陷波超宽带天线实物图

6　结束语

本文将稀疏正则化逆向神经网络与 HFSS 联合的方法应用到双陷波超宽带天线的设计中，该逆向设计方法不需要建立单独的逆模型，在正模型的基础上实现逆向设计功能，逆模型精度更高，网络泛化能力更强；联合 HFSS 仿真软件，根据天线目标电参数逆向求解对应的几何参数，提高了设计效率；该超宽带天线可以滤除 WIMAX 和 WLAN 频段的干扰，实现了良好的双陷波特性。下一步计划提出更加高效的神经网络逆向建模方法，使用神经网络和 HFSS 联合优化的方法设计出多款性能更好的天线及天线阵。

参考文献：

[1] 李桐. 认知无线电中超宽带与频率可重构天线的研究 [D]. 西安: 西安电子科技大学, 2014. (Li Tong. Study on ultra-wideband and frequency reconfigurable antennas for cognitive radio systems [D]. Xi, an: Xidian University, 2014.)

[2] 孙荣辉, 高卫东, 刘汉, 等. 一种新颖的双陷波超宽带天线设计 [J]. 微波学报, 2012, 28 (2): 63-66. (Sun Ronghui, Gao Weidong, Liu Han, *et al.* Design of a novel dual band-notched ultra-wideband antenna [J]. Journal of Microwaves, 2012, 28 (2): 63-66.)

[3] Ojaroudi M, Ojaroudi N, Ghadimi N. Dual band-notched small monopole antenna with novel coupled inverted U-Ring strip and novel Fork-Shaped slit for UWB applications [J]. IEEE Antennas and Wireless Propagation Letters, 2013, 12 (1): 182-185.

[4] Kabir H, Yu Ming, Zhang Qijun. Recent advances of neural network-based EM-CAD [J]. International Journal of RF and Microwave Computer-Aided Engineering, 2010, 20 (5): 502-511.

[5] Zhang Qijun, Gupta K C, Devabhaktuni V K. Artificial neural networks for RF and microwave design-from theory to practice [J]. IEEE Trans on Microwave Theory and Techniques, 2003, 51 (4): 1339-1350.

[6] 南敬昌, 桑百行, 高明明. 基于高频结构仿真器和神经网络的双面双频宽带偶极子天线设计 [J]. 计算机应用, 2014, 34 (10): 3044-3047. (Nan Jingchang, Sang Baihang, Gao Mingming. Design of dual-band wideband dipole antenna based on HFSS and NN [J]. Journal of Computer Applications, 2014, 34 (10): 3044-3047.)

[7] Kabir H, Wang Ying, Yu Ming, *et al.* Neural network inverse modeling and applications to microwave filter design [J]. IEEE Trans on Microwave Theory and Techniques, 2008, 56 (4): 867-879.

[8] Vai M M, Wu Shuichi, Li Bin, *et al.* Reverse modleing of microwave circuits with bidirectional neural network models [J]. IEEE Trans on Microwave Theory and Techniques, 1998, 46 (10): 1492-1494.

[9] Mareddy L, Almkawi M, Devabhaktuni V, *et al.* Gradient based reverse ANN modeling approach for RF//microwave computer aided design [C]// Proc of the 7th European Microwave Integrated Circuits Conference. 2012: 246-249.

[10] Gosal G, Mcnamara D A, Yagoub M C E. The use of inverse neural networks in transmitarray antenna Design [C]// Proc of IEEE Antennas and Propagation Society International Symposium. 2014: 1272-1273.

[11] Gosal G, Almajali E, D Mcnamara, *et al.* Transmitarray antenna design using forward and inverse neural network modeling [J]. IEEE Antennas and Wireless Propagation Letters, 2016, 15: 1483-1486.

[12] 孔繁锵，王丹丹，沈秋. L1-L2 范数联合约束的鲁棒目标跟踪 [J]. 仪器仪表学报, 2016, 3 (37): 690-696. (Kong Fanqiang, Wang Dandan, Shen Qiu. Robust object tracking via L1-L2 norm simultaneous constraint [J]. Chinese Journal of Scientific Instrument, 2016, 3 (37): 690-696.)

[13] Xu Zongben, Zhang Hai, Wang Yao, *et al.* L1//2 regularization [J]. Science China-Information Sciences, 2010, 53 (6): 1159-1169.

[14] 黄炳家，王健，温艳青，等. 带光滑 L1//2 正则化项的神经网络逆向迭代算法收敛性分析 [J]. 中国石油大学学报：自然科学版, 2015, 39 (2): 164-170. (Huang Bingjia, Wang Jian, Wen Yanqing, *et al.* Convergence analysis of inverse iterative algorithms for neural networks with L1//2 penalty [J]. Journal of China University of Petroleum: y: Natural Science, 2015, 39 (2): 164-170.)